

数据分析与知识发现 Data Analysis and Knowledge Discovery ISSN 2096-3467,CN 10-1478/G2

《数据分析与知识发现》网络首发论文

题目: 科技文献评价中语义新颖性研究综述 作者: 吴欣雨,李涵昱,张智雄,吴振新

网络首发日期: 2023-10-18

引用格式: 吴欣雨,李涵昱,张智雄,吴振新.科技文献评价中语义新颖性研究综述

[J/OL]. 数据分析与知识发现.

https://link.cnki.net/urlid/10.1478.G2.20231018.1151.004





网络首发:在编辑部工作流程中,稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定,且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件,可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定;学术研究成果具有创新性、科学性和先进性,符合编辑部对刊文的录用要求,不存在学术不端行为及其他侵权行为;稿件内容应基本符合国家有关书刊编辑、出版的技术标准,正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性,录用定稿一经发布,不得修改论文题目、作者、机构名称和学术内容,只可基于编辑规范进行少量文字的修改。

出版确认:纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约,在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版,以单篇或整期出版形式,在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z),所以签约期刊的网络版上网络首发论文视为正式出版。

网络首发时间: 2023-10-18 19:13:19

网络首发地址:https://link.cnki.net/urlid/10.1478.G2.20231018.1151.004

科技文献评价中语义新颖性研究综述

吴欣雨 李涵昱 张智雄 吴振新

(中国科学院文献情报中心 北京 100190)

(中国科学院大学经济与管理学院信息资源管理系 北京 100190)

摘要:[目的]对国内外语义新颖性研究相关进展进行归纳整理,总结相关技术,为后续研究 提供参考。[文献范围]利用"Novelty of the literature" "semantic novelty" "文献新颖性" "语义新颖性 and 文献评价"等检索式进行检索,经过阅读整理并对具有代表性的相关理 论研究进行溯源,最终筛选出70篇文献进行评述。[方法]对国内外语义新颖性相关研究 进行总结梳理,围绕新颖性定义、新颖性评价指标和不同评价方法等分析科技文献语义新 颖性评价的发展现状及未来趋势。[结果]语义新颖性评价逐渐受到学界的广泛关注,已有 相关研究对语义内容进行挖掘评价,但尚未形成统一的度量指标。[局限]现有的文献新颖 性多从外部特征进行评价,直接以语义新颖性为主题的研究文献数量较少,在支撑综述方 面存在局限性。[结论]科技文献的语义新颖性评价根本在于语义内容的新颖性,定量研究 已成为主流研究方法,但评价指标的计算方式尚需明确,未来的新颖性评价发展方向应结 合定性与定量方法全面分析, 实现科学、合理的综合学术评价。

关键词: 新颖性评价; 语义评价; 文献计量; 语义新颖性

分类号: G250

DOI:10.11925/infotech.2096-3467.2022.1226

Review of Semantic Novelty in Scientific Literature Evaluation

Wu Xinyu Li Hanyu Zhang Zhixiong Wu Zhenxin

(National Science Library, Chinese Academy of Sciences, Beijing 100190, China)

(Department of Information Resources Management, University of Chinese Academy of Sciences, Beijing 100190, China)

Abstract:[Objective] This paper reviews the relevant progress of semantic novelty research at home and abroad, and summarizes the relevant technologies to provide reference for the subsequent research. [Coverage] Using retrieval methods such as "Novelty of the literature", "semantic novelty", "literature novelty", "semantic novelty and literature evaluation", after reading and sorting, this paper traced the source of representative relevant theoretical researches, and finally selected 70 literatures for review. [Methods] This paper summarizes the relevant researches on semantic novelty at home and abroad, and analyzes the development status and future trend of semantic novelty evaluation in scientific and technological literature by focusing on the definition of novelty, evaluation indexes of novelty and different evaluation methods. [Results] Semantic novelty evaluation has gradually attracted widespread attention from the academic community. There have been related studies on semantic content mining and evaluation, but no unified measurement index has yet been formed. [Limitations] The existing literature novelty is mostly evaluated from external features, while the number of literatures directly focusing on semantic novelty is small, which has limitations in supporting the review. [Conclusions] The evaluation of semantic novelty of scientific and technological literature is based on the novelty of content. Quantitative research has become the mainstream research method, but the calculation method of evaluation index needs to be clarified, and the development direction of novelty evaluation should be combined with qualitative and quantitative methods to achieve a scientific and reasonable comprehensive evaluation.

Keywords: Novelty evaluation; Semantic evaluation; Bibliometrics; Semantic novelty

1 引言

科技论文作为学术成果的重要体现和传播方式之一,在整个科研流程中起到展示新观点、传播新理论、应用新技术等重要作用,对学术论文进行评价有利于激发科研人员积极性,进而推动产生高质量成果。国家标准 GB7713-87《科学技术报告、学位论文和学术论文的编写格式》中将学术论文定义为"某一学术课题在实验性、理论性或观测性上具有新的科学研究成果或创新见解和知识的科学记录"^[1],从论文自身的属性来看,其评价的本质是学术价值评价^[2],首要标准则是论文是否具有创新性及创新性的程度。

作为创新性度量的一个重要角度,文献的语义新颖性反映了领域研究知识的前沿和发展趋势,语义内容的新颖性评价也逐渐受到研究者们的关注。目前我国的科技文献新颖性评价多以文献计量指标为主,过度强调文章的被引频次、发表期刊影响因子等外在指标,缺乏深入到论文内容层次的评价方法^[3]。随着文本挖掘技术的发展,大数据和人工智能等技术逐渐被应用到文献计量学中,新颖性评价也由外在指标评价转向了语义内容评价,论文本身的知识结构和语义的复杂性要求研究者们不断去探索更完善的度量方法,为科技文献的新颖性评价提供更好的切入点,从而便于科研人员对自身和已有的研究成果新颖性进行评估,把握研究前沿。

基于此,本文结合科技文献新颖性评价的最新研究成果,较为系统、全面的对语义新颖性概念、内涵、评价指标和评价方法进行归纳,梳理语义新颖性评价流程,总结研究重点与方法技术。首先,通过对近年发表的主题文献和相关知识概念进行整理,明确新颖性定义及语义新颖性内涵;其次,分析论文新颖性度量的外部指标与语义评价指标,根据侧重点的不同进行优劣对比;最后,从评价方法和关键技术等角度出发,对语义新颖性评价进行综合述评,并提出当前的技术局限性与研究展望。

2 科技文献语义新颖性评价

2.1 相关概念辨析

创新的概念最早起源于J. A. Schumpeter提出的创新理论(Innovation Theory),认为创新 是一种革命性变化,必须能够创造出新的价值。创新理论的发展使其延伸出了不同的类 型与研究应用场景,不同性质的研究,其创新类型也不尽相同,如基础研究多容易产生创 造性的新知识方法,从而形成原始创新:应用研究则可能会对已有知识进行重组或完善, 产生集成创新或消化吸收再创新等。结合世界知识产权组织、经济合作与发展组织、欧洲 联盟等重要科学组织对创新的定义[5.6.7],通过归纳总结,创新的基本类型可分为以下几 点: ①产生前所未有的新理论、规律或技术方法,具有原创性;②对已有知识和技术进行 的重新组合或集成; ③在已有知识和技术的基础上进行改进完善, 形成创新。而针对学术 文本,研究者们对其"创新"概念还未形成统一的定义,多使用新颖性、颠覆性、创新力 等来指代,在国外文献中常以innovation、novelty、disruptive innovation等词汇出现,以便 从创新的时间、内容、价值、后续影响力层面描述创新的特征^[8]。一些学者从不同角度提 出了关于创新性的概念,如高自龙认为创新性学术首先指在思想、理论、观点、方法上有 创新,最终体现在人们对其学术和社会价值的评价判断上^[9]: 索传军从学术论文内容的角 度出发,指出论文的创新性体现在被科研人员的广泛引用上,因为其包含有引用者不具备 的知识[10]。由此可见,针对学术文本的创新性评价主要体现在研究的后续影响力与应用价 值。

虽然目前学界对创新性的定义不尽相同,但其论述均体现了"新"这一本质特征,这也使目前的研究聚焦到了新颖性上。作为创新性的重要组成部分,在不同的应用对象和场景下,对于新颖性的定义也有所不同。在科技查新中,新颖性主要指在查新委托日以前查新项目的科技内容部分或者全部没有在国内出版物上公开发表过[11]。本文整理了国内外部分研究者们对于新颖性的定义,如表1所示。

Table 1 The concept of novelty

作者	新颖性概念阐述	
张京辉等 ^[12]	新颖性指在国内外的研究中是否已经出现过,或者已有类似研究,但因研究 进展变化需要进行补充、修订和完善	
陈永胜等[13]	科技成果的新颖性主要取决于公开发表的时间先后顺序	
徐华[14]	认为科技论文的新颖性主要体现在对新的概念、数据、假设、定理等进行增删、修改、补充等,或对已有的应用范围和方法对策进行了修正、改进,或 提出了新的思想和新发明	
魏绪秋等[15]	学术论文的"新"在于是否提出了新理论与新观念、新方法技巧和已有问题 的新解释与结果	
S.Mishra 等 ^[16]	学术论文的新颖性体现在引入新的观点,包括从未出现过的新观点和增加已 有的确定观点	
T.Heinze 等 ^[17]	具有新颖性的学术论文应具有革命性的新理论、发现新现象、创建新方法及 从新角度整合的研究成果	
K.Sarah 等 ^[18]	从知识组合的角度出发,新颖性是由先前存在的知识的不寻常组合发展而来	

通过对以上概念的总结与归纳发现,针对学术成果而言,创新性并不等同于新颖性,二者之间既有区别也有联系:创新性和新颖性都关注学术成果是否提出了新的理论方法或技术路线,但两者对比而言,新颖性更强调时间维度上的"新",侧重于科研成果发布前或发布时所展现的"第一性",但新颖的文章主题或研究概念并不一定具有实际的研究价值;创新性则侧重新的科研成果发布后产生的影响,更强调后续的应用价值和学术影响。

2.2 科技文献语义新颖性内涵

科技文献中包含了研究背景、目的、问题、方法与结论等一系列要素,这些要素主要以词语、句子、段落等文本形式表达,黄红等[19]认为科技文献语义内容单元就是文中表示特定科研要素的文本单元。Z.Nasar等[20]则将科技文献语义内容分为研究问题、研究领域、解决方法、实验数据、应用工具、评价方法、研究结果、研究局限及未来发展 9 种类型。通过对有关研究的归纳总结,科技文献的语义内容主要包括:①研究背景、目的、问题、方法、结果、结论等语步;②研究技术、软件系统、理论原理、数据资料等科研实体;③概念定义、术语、公式等语义特征。

综合现有研究,基于前文所述的新颖性与内容语义单元概念,本研究认为,科技文献语义新颖性是指在文献中提出了不同于以往研究的语义内容,包括提出新研究问题与方法、得出新研究结果与结论、使用新研究技术与数据、定义新概念与特征等,或对已有研究中的语义内容进行改进或完善。基于以上有关创新性、新颖性及语义新颖性的概念研究,本文借鉴 K.Sarah 从知识组合角度出发对新颖性的定义,对三者进行辨析,如表 2 所示。

表2 创新性与新颖性、语义新颖性辨析

Table 2 Analysis of innovation, novelty and semantic novelty

创新性 新颖性 语义新颖性

提出新观点、理论、技术,或对 已有理论和方法进行完善,改进 或创造新事物,并能产生一定影 响力或有益成果

率先提出新理论、方法;或从 知识组合的角度,指对先前存 在知识的新角度整合 提出了不同于以往的研究语义 内容;或对已有研究中的语义 内容进行改进或完善 兼具有用性、新颖性、价值性与变革性,重点在于带来了积极的社会变化或创造价值
一般为学者、期刊或高校、研究院所等科研机构通过创新活动产生的创新成果

新颖性维度、研究价值维度、影响力维度

评价方式

多使用颠覆性指数、被引频次等 指标衡量影响力,同时结合文本 新颖性进行评价 侧重于时间维度上提出的"首次"与"不同",不考虑价值 或后续的影响

一般为科技文献或其他文本

时间维度、引文维度、内容维 度

多使用基于引文分析、基于内容分析方法进行文献外部或内部特征的新颖性计算

侧重于科学研究中语义内容的 "第一性",一般具有实际的 研究价值

一般为科技文献中的语义内容,包括研究问题、研究方法等语步

时间维度、语义内容维度

多使用相似度计算等指标衡量 文章语义内容的新颖性程度

科技文献的新颖性是文章创新性评价的一个重要特征,往往代表了该研究的创新能力和影响力水平,也是衡量科技发展趋势的重要指标。阅读新颖性较高的文章可以提高研究人员的阅读效率,使其尽快掌握科学前沿动态,意义重大。传统论文的新颖性通常使用引文网络分析法、作者合著分析法等对相应指标进行量化计算,以引用不同类型期刊、多学科学者之间的合著情况来反映学科知识融合产生的新颖性[21]。随着自然语言处理技术的发展,论文的新颖性研究深入到了文章内容层次,通过词语抽取方式直接揭示论文本身的新颖性,且不受引文数量、作者研究领域等外部特征的影响[22]。但单纯的词语抽取新颖性评价存在一定的弊端,即某些"不同于以往"的词语本身无法代表该研究在内容或结果方面有实质性创新,而看起来"用词不新"的文章可能真正具有实质创新。而针对语义内容的研究结合了知识抽取相关技术,通过对论文的研究背景、研究问题-方法、研究结论、所使用方法技术等语步的识别[23],实现针对文章内容的全方位、多角度语义挖掘,为实质的科研成果新颖性提供了研究基础。语义新颖性科技文献的语义新颖性评价流程如图1所示。



图 1 科技文献的语义新颖性评价流程图

Fig.1 Flow diagram of semantic novelty evaluation of scientific and technological literature

3 语义新颖性评价指标

文献本身作为知识的载体,所承载的知识内容复杂且价值表现多样,国内外研究者也从多个维度对学术论文评价展开了研究。目前应用于科技文献评价的可量化指标较多,应用最广泛的是期刊及会议论文相关的衍生指标,包括期刊影响因子、论文数量指标等^[24],但针对各个学科和各类论文仍没有普适性的评价指标。传统的论文新颖性评价指标主要从

时间维度和引文维度两个方面考量。但在科技文献语义评价中,由于不同的语义挖掘方式和作者定义的计算方法不同,针对文献内容的新颖程度还没有统一的衡量指标。

3.1 传统科技文献新颖性评价指标

由于新颖性的本质特征重点强调时间维度,学界普遍认为文献发表的时间越晚,其相对的新颖性可能就越高。除了文献本身的发表时间以外,也有一些适用于参考文献发表时间的计量指标。学界针对论文新颖性指标主要使用"被引文献的平均发表时间"和"类簇论文的平均发表时间"来衡量^[25]。I. Jarić 等^[26]假设引文的相对年龄受科学领域趋势的影响,可以用于识别新颖的文章主题,同时提出了使用被引文献的平均发表时间作为评价文章新颖性的指标。P.Llorente 等^[27]针对领域的不同主题论文进行聚类,以类簇论文的发表平均时间来衡量文献和期刊对该领域发展的新颖性和贡献度。总体来说,以时间维度衡量文章的新颖性是最直观的评价指标。

除了时间维度衡量以外,有学者将文章引文作为新颖性的衡量指标,这其中应用最为广泛的就是颠覆性指数。2017年,R.Funk等^[28]首次提出颠覆性指数的概念,用于测度科研成果的原创性。颠覆性指数通过目标文献发表后,引文网络是否发生了转移及转移程度来衡量文献的颠覆性,若目标文献的施引文献仅引用了目标文献而没有引用目标文献的参考文献,则认为该文献具有颠覆性。

目前通过引文进行新颖性衡量的角度主要有三种:参考文献角度^[29,30,31]、焦点论文角度^[32,33]和施引文献角度^[34,35]。从参考文献的角度来说,论文的新颖性侧重于参考文献所属学科的组合新颖性,但这种角度的局限性在于仅侧重了组合的新颖程度,而忽略了论文成果的有用性及后续的研究影响。从焦点论文的角度进行新颖性度量的方法主要依靠文章的概念年龄和主题词表,主题词表的更新是否及时、文本内容的挖掘是否准确成为了需要解决的问题。从施引文献的角度来说,焦点论文的被引情况一定程度上反映了论文的新颖性和原创性,同时也衡量了焦点论文对于后续科研活动的影响,该角度测量的典型指标就是颠覆性指数^[36]。相较于其他计量指标而言,颠覆性指数在衡量文献新颖性上更侧重于焦点论文带来的后续研究价值,与科研评价的最终目的一致,因此,颠覆性指数比其他计量指标更适合进行文章新颖性的度量。

3.2 文献语义新颖性评价指标

针对评价指标而言,时间维度与引文维度都属于文章的外部特征,不涉及针对文章内容新颖性的评价。如何更好地挖掘文本内容信息,真正实现全方面、多维度的语义新颖性评价成为目前学界的研究热点。

M.L.Frigotto 等 $^{[37]}$ 结合专家问卷调查的方式,使用论文作为基本的分析单位来衡量作者的创造性。这项研究将论文视为一组作者(a)和概念(c)的组合,定义了论文的新颖性计算公式:

$$n_s(p) = \{t(c), t_s(c); t(c^2) \setminus t(a), t_s(a); t(a^2)\}$$
 (1)

该公式包含概念(c)之前在文献中出现的次数、专业领域中出现的次数以及两个概念同时出现的次数,同时包含作者(a)的所有论文数量、专业领域中的论文数量以及两位作者合著的次数。该指标融合论文的概念内容和外部特征的新颖性,首次深入到文献的内容层次来衡量科学创新^[38]。

随着文本挖掘技术的不断成熟,文献的新颖性评价越来越侧重于文本内容,语义评价指标也开始摆脱外部指标的影响,真正深入到内容层面。Y.Zhang等^[39]使用余弦相似度的方法计算中文文档和句子新颖性度量,并给出了新颖性指标 NoveltyScore 的计算公式:

Novelty Score(
$$d_t$$
) = 1 - $\max_{1 \le i \le t-1} \cos(d_t, d_i)$ (2)

$$\cos(d_t, d_i) = \frac{\sum_{k=1}^{n} w_k(d_t) \cdot w_k(d_i)}{\|d_t\| \cdot \|d_i\|}$$
(3)

该公式使用 $N_{cos}(d)$ 表示文档或句子 d 的余弦相似度得分,使用词频作为术语加权函数来计算句子加权向量中每个元素的权重,并设定新颖性阈值,通过计算目标文档/句子与历史文档/句子之间的相似性得分来评价其新颖性。

除了完全使用文章的语义内容作为计算指标以外,论文发表时间也被纳入考虑范围中辅助评价新颖性。杨建林等^[40]通过定义带时间戳的关键词对逆文档频率(Time-Stamped Inverse Document Frequercy of keyword Pair,KPTIDF),提出了针对文档的主题新颖性计算指标:

$$NOV(D) = \frac{\sum_{1 \le i < j \le n} KPTIDF(D, t_i, t_j)}{n \times (n - 1 \times 0.5)}$$
(4)

以论文的发表期刊出版时间作为时间戳,同时基于关键词对的逆文档频率进行计算,弥补了单个关键词反映新颖性程度较弱的缺点。该指标将语义内容与论文发表时间融合,既考虑文章主题内容新颖程度,又融合论文发表的时间维度,形成科学、合理的新颖性评价方式。

3.3 新颖性评价指标对比分析

总体来说,上述新颖性指标虽然都能较好的解决部分论文新颖性评价问题,但仍存在 局限性。本文在针对不同的指标的侧重点,归纳总结了科技文献新颖性评价指标的优劣对 比,见表 3。

表 3 现有科技文献新颖性评价指标对比

Table3 Comparison of Novelty Evaluation Indexes of Existing Scientific and Technological Literature

指标类型		优势	劣势
传统科技文献 新颖性评价指 标	时间维度	时间维度较为直观, 易于计算。	评价维度单一,无法反应论文对 后续科研成果的影响和科学价 值。
	引文维度	较好的评价了学术成 果的引文新颖性和后 续影响力。	过于依赖对文章参考文献的分析,需要较多的不同类型施引文献的数量才能满足计算;新颖性识别缺乏及时性。
语义新颖性评价指标		忽略了外部特征的影响,真正深入文章内容层次进行新颖性评价。	由于针对内容的文本挖掘方式和 新颖性计算方式不同,无法形成 统一的度量指标。

针对整个文章而言,时间维度和引文维度都可以作为衡量新颖性的指标,但其局限性在于完全脱离了文章内容,且如果存在类似于"睡美人"论文的零被引文章类型,或由于引文时间窗而造成焦点论文未被引用的情况,基于时间和引文维度的评价指标无法真正评判论文的新颖性。科技文献的语义新颖性评价通过对语义内容进行挖掘和分析,实现针对

内容实质新颖性的综合评判,相较于外部特征而言,更具有科学性和合理性。未来科技文献的新颖性评价指标可以结合引文指标与语义指标的结合,在识别文章语义内容的同时, 关注时间维度与引文关系中的"新颖性"^[41]。

4 语义新颖性评价方法

早在1996年9月,美国就出现了关于新颖性探测(novelty detection)的相关研究,美国国防部DARPA(Defense Advanced Research Projects Agency)发起了主题探测与追踪的子项目,在信息流中探测首次提到的话题报道。2002年,作为文本信息检索领域最权威的国际性评测会议,TREC(text retrieval conference)开始在会议上增加文本内容新颖性追踪探测的项目,通过找到文章中的主题相关句子和新颖性句子,生成有序文档[42],自此文本内容的新颖性研究开始受到了研究者们的广泛关注。科技文献的本质是承载研究成果的书面文本,且随着大数据与语义技术的发展,传统以科学学、计量学为基础的评价理论和方法已不能满足研究需要,对科技文献的文本内容进行语义新颖性评价研究成为构建科学评价体系的重要方法。

目前针对科技文献语义新颖性的评价方法主要分为定性方法和定量方法。其中定性方法主要是同行评议法,通过领域专家对自身研究方向和学科发展现状的了解和认知,对科技文献的主题及内容新颖性进行综合的、公平公正的判断。这种方法无关于论文作者的代表作及被引次数的多少,而是通过论文本身去评判文章的论证内容、主题及研究方法的新颖性和学术应用价值^[43]。这种定性评价的方法虽然可以帮助领域外的研究人员更快的了解文献的知识结构,但多依靠专家的主观判断和个人认知,存在一定的主观性和非全面性,缺乏具体的量化指标,且费时费力。

科技文献的语义新颖性评价定量方法主要使用的是基于内容分析方法,通过针对科技 文献的具体词语、主题、研究内容等文献语义内容进行挖掘,实现文献新颖性的量化。在 已有的研究中,主要包括向量空间模型和主题探测追踪两种方法。本文将重点论述不同的 语义新颖性度量方法的评价方式及优劣。

4.1 向量空间模型法

空间向量模型法是现有的新颖性评价方法中起步最早、应用最为广泛的,国内外学者也基于此方法展开了一系列研究。邢美凤等[44]认为向量空间模型法包括相似度计算法、命名实体识别法、基于聚类方法、基于K近邻方法和基于神经网络的方法。目前应用最广泛的就是相似度计算法,该方法主要依赖于空间向量的两两相似度计算,文本相似度越小,则新颖性越高。除了相似度计算外,基于距离的方法也常被用于新颖性计算。这种方法通过文献之间的距离来衡量文献的相似性,进而判断文献的新颖程度,目前研究多使用K近邻法和基于Hellinger距离方法。通过总结归纳,不同学者使用向量空间模型法的语义新颖性研究如表4所示。

表4 向量空间模型法的语义新颖性研究

Table4 The semantic novelty of the vector space model method

类型	作者	研究方法
相似度计算 方法	逯万辉等[45]	使用 Doc2Vec 和 HMM 算法,通过构建相似度转移矩阵、计算特征因子来计算文档集中各个文档的相似程度,进一步判断文档的新颖性程度。
	S.Tsai 等 ^[46]	使用对称性度量(余弦相似性和 Jaccrad 相似性)和不对称度量(新词数和重叠数),并基于两种度量方式构建了综合新颖性评测框架。
	王平等[47]	使用 Doc2Vec 语言模型构建文本向量,并基于张量神经网络模型 (Neural Tensor Network, NTN)来训练求解,量化评估文章的新颖性。
	Z.Luo 等 ^[48]	使用 BERT 模型来训练词向量,通过向量之间的相似性反应语义间的相似性。

	褚婧丹[49]	构建科技词向量,使用文本语义相关二分类模型来判断当前词与候选文 献集中的相似程度
	陈娜[50]	根据语义层面的相似度,使用链路预测技术,结合知识元的共现次数及 未来链接概率综合评价技术文本的新颖性
基于距离的 方法	S. Sendhilkumar 等 ^[51]	在 LDA 主题模型的基础上,使用余弦相似度计算两个文档主题分布之间 的差异,以此分析特定科学领域的论文新颖性
	秦岩等[52]	使用 TF-IDF 计算文本概念向量的余弦相似度,再由相似度计算得到会议论文的产出新颖性指标,以此来计算会议论文的新颖性程度
	V.Hautamaki 等 ^[53]	使用分类器将旧文档划为 K 个聚簇,然后衡量目标文档与每个聚簇中心 点的位置来对文档类别进行判断,最后将该文档与聚簇之间距离最近的 点进行相似度计算[54]
	K.Zhang 等 ^[55]	使用基于 Hellinger 距离的索引树聚类方法,计算新闻话题文本的相似度,同时引入了时间参数来衡量文本的新颖性。

4.2 主题探测追踪法

主题探测追踪法是针对目前研究领域较为前沿的热点建立模型,通过关键词、主题词和词频等指标对文献新颖性进行量化。这种方法深入到了文章的主题内容中,重点强调关键词、文章主题等具有语义信息的新颖性评价。随着语步识别技术的发展,科技文献中的研究背景、研究问题、研究方法等核心内容的抽取助力了文献的评价指标量化,尤其是针对问题-方法短语的新颖性评价成为了研究热点,但基于研究背景、研究结论等语义内容的新颖性评价仍较少开展。通过总结归纳,不同学者使用主题探测追踪法的语义新颖性研究如表5所示。

表 5 主题探测追踪法的语义新颖性研究

Table5 Semantic novelty of topic detection and pursuit

类型	作者	研究方法
研究主题共现 法	R.K.Amplayo 等	将神经网络算法模型与主题新颖性探测相结合,通过构建主题共现图的 方法,对研究论文主题背景图的变化特征进行提取,使用自编码神经网 络进行新颖性识别
	丁芳媛[57]	在 R.K.Amplayo 研究的基础上设计基于主题共现图的论文新颖性评价与 推荐算法
	任海英等[58]	在文献中抽取主题词并构建领域主题词共现网络,设计新颖组合率、中等组合率和常规组合率三个指标,以此来评估论文主题的新颖组合和常规组合对论文新颖性类型的影响
主题词语计算 法	K.Matsumoto 等	使用有序逻辑和普通最小二乘回归模型,提出了一种新颖性指标来量化 焦点论文主题与同领域论文之间的相似程度
	许丹等[60]	使用自然语言法,基于共现原则、时间点原则和自然语言词对逆文档频 率原则来计算文档主题新颖度
	杨京等[61]	利用 Keygraph 算法提取代表论文研究主题的关键词,与科学研究前沿主题进行计算比较,结合期刊影响因子和 Altmetrics 两项外在指标进行评价

张吉玉等[62]

将文献按照时间序列构成索引,并投影在问题-方法矩阵中,以此来评价 研究内容在时间方面的新颖性

语义信息抽取 法 钱佳佳等[63]

通过对问题和方法短语进行识别,基于词频原则分别计算短语新颖度和问题-方法组合新颖度,再对其赋予不同的权重进行文章的新颖性计算,证明基于问题和方法短语进行新颖性度量的科学性

王艳艳等[64]

使用 LDA 主题模型对论文的问题和方法短语进行分类,构建问题-方法 矩阵并实现论文新颖性查询

曹树金等[65]

通过语义角色标注法,使用 BERT 模型识别创新句并匹配到文章中的创新段,实现基于语义信息的完整段落新颖性挖掘

5 现存问题与研究展望

通过对文献梳理和研究总结,本文分析了科技文献语义新颖性研究中存在的主要问题,并依据研究趋势和不足之处对其未来发展进行了展望。

5.1 现存主要问题

目前由于科技文献的语义新颖性评价流程主要包括两个方面,即语义内容的挖掘和新颖性评价,本文对于现存主要问题的分析也围绕这两个方面展开。

- (1) 语义内容挖掘问题
- ①语义内容标准类型不一

科技文献作为科研工作的重要载体,以文本内容实现对科研工作的描述论证,其中包含了多种类型的语义内容,形成相对统一的划分标准是实现语义内容自动识别的基础。但目前针对文献语义内容的研究需对不同论文结构采用不同建模方式,导致语义类型划分依据不统一,因此语义内容会出现交叉、重叠和冲突的现象。且不同的研究者对于语义内容的理解存在不同,导致其范围、内容和特征无法被准确描述,这会影响语义内容挖掘技术对其特征信息的利用,限制技术的通用性。

②挖掘方法存在局限

由于目前公开标注的数据集存在"中文开源语料稀缺"和"所属领域集中于自然科学领域"等问题^[66],自建的标注数据集规模较小,且存在人工标注偏差,数据标注结果缺少权威认可,导致现有的语义挖掘方法缺乏普适性验证。此外,深度学习方法作为当前的主流方法,对于数据量、设备性能的要求较高,使用场合受限,且目前的语义内容挖掘方法在许多研究领域还未达到较好的准确性,无法满足大规模现实应用的需要。

③挖掘重点不平衡

通过对语义内容挖掘相关研究进行归纳发现,目前研究点主要集中在研究问题及研究 方法的短语抽取,对其他语义类型的挖掘较少。近年来,随着科研评价体系的不断发展完善,学术论文中的创新点、研究背景、研究结论等信息也开始逐渐被学者们利用,但目前 针对这类语义内容的挖掘工作仍然较少。此外,目前研究中所利用的摘要、关键词、标题 等短文本挖掘包含的语义关系与干扰信息相对较少,挖掘难度也较小;而论文章节或全文 中包含的语义内容更丰富,但同时无用信息也较多,挖掘难度也较高,使大量的信息难以 利用。

(2) 新颖性评价问题

①评价维度存在误区

前文提到目前新颖性评价常与创新性评价混为一谈,这一误区使研究中常有使用论文主题的新颖性指标来衡量论文创新性的情况,导致评价结果的不准确性。且目前许多研究

单纯通过引文维度衡量论文新颖性,包括期刊影响因子、引文数量指标等外在指标,造成了评价完全脱离论文实质性内容的问题。

②评价指标设计主观性强

由于当前的新颖性评价方法多使用基于内容的方法,学者们对于语义内容的挖掘方式不同,更难以形成统一的衡量指标。且在设计指标时,评价者难免受到个人主观意愿的影响,将个人的认知与评价期待带入设计过程中,当前的科技文献新颖性评价仍缺乏相对统一的指标体系与研究框架。

③评价体系局限于特定领域

目前,科技文献新颖性评价的研究大多集中在人文社科等领域,学科的差异性会导致论文语义内容相关的特征指标权重不同。因此大多数研究中提出的方法仅针对于同领域、同类型的文献评价,不具有普遍适用性[67]。

5.2 未来研究展望

近年来大数据技术与深度学习技术蓬勃发展,为文本内容的自动挖掘与分析提供了重要的技术支撑,也为科技文献的语义新颖性评价研究带来了新的发展契机,基于此,本文对未来的研究方向做出了展望。

(1) 充分挖掘科技文献内容语义特征

科技文献的语义内容特征是新颖性评价的重要依据,使用数据挖掘技术对特征进行自动识别可以更加科学与高效。除了主题词、关键词等内容,不同语义类型之间的关系也值得关注,包括同一粒度对象之间和不同粒度对象之间的语义关系,构建论文逻辑链。未来的研究应注重挖掘更多的语义内容特征与关系网络,为语义新颖性评价提供可靠的数据支撑,促进语义内容的知识组织与利用。

(2) 扩展语义内容挖掘的研究路径

目前深度学习技术作为语义内容挖掘的主流手段,其具有很强的信息提取能力,且模版化程度高,研究者们多选择直接套用常见的技术框架进行内容挖掘,缺乏对语义内容的特征融合和方法思考。未来的研究应拓宽知识挖掘思路,除了对于主题词、关键词等进行挖掘外,可以借助表格、图片等除了文本以外的特征实现多模态内容挖掘模型,全方位地对论文新颖性进行评价。

(3) 增强论文评价的科学性与智能性

不同学科和类型的科研领域应健全分类指标评价体系,以学科特色为基础提出各自的语义新颖性评价侧重点与评价指标,为新颖性评价提供科学的评判标准,促进科技文献评价工作健康有序开展。同时,语义新颖性评价需要综合时间维度、引文维度和语义内容信息,兼顾内外在指标,全面客观地反映学术论文的新颖性程度。同时应增强评价的智能性,深度结合自然语言处理等相关技术,实现学术论文中创新点、创新句及创新段落的自动挖掘,结合对同行评议文本进行情感分析所得到的情感倾向性^[68],构建智能论文评价模型。

6 结语

目前我国科研活动的发展态势良好,国家正在大力推进科研评价,推进创新驱动。论文作为学术成果的主要载体,其新颖性的重要程度不言而喻。为了衡量科技文献的语义新颖性,更好地推动科研评价与创新,本文介绍了科技文献语义评价新颖性的度量指标,对比分析了基于内容新颖性评价的不同方法及其优劣。教育部在《第五轮学科评估工作方案》中明确指出,要"充分运用基于定量数据和客观证据的专家融合评价方法,坚持代表性成果专家评价与高水平成果定量评价相结合"[69]。也有学者认为,学术评价应挖掘多维度的定量指标,实现基于客观证据与定量指标的综合评价体系,从而为同行评议提供数据

支撑^[70]。论文的新颖性评价根本还是在于内容的新颖程度,未来针对科技文献语义新颖性的研究应结合定量的内容分析和定性的同行评议方法,对论文内容进行深层次的揭示和把握,科学、合理的实现科技文献的语义新颖性评价。

参考文献

- [1] 科学技术报告、学位论文和学术论文的编写格式[S/OL].[2017-09-20]. https://wenku.baidu.com/view/d837882a13a6f524ccbff121dd36a32d7275c741.html.
- [2] 索传军,盖双双,周志超.认知计算——单篇学术论文评价的新视角[J].中国图书馆学报, 2018. 44(1):50-61.
- [3] 曾建勋.推动科研论文语义评价体系建设[J].数字图书馆论坛,2021,(11):1.
- [4]熊彼特.经济发展理论[M].邹建平译.北京:中国画报出版社,2012.
- [5]WIPO.The Direction of Innovation[EB/OL].(2023-2-23).[2023-2-
- 23].https://www.wipo.int/edocs/pubdocs/en/wipo-pub-944-2022-en-world-intellectual-property-report-2022-the-direction-of-innovation.pdf.
- [6]OECD.Oslo Manual:guidelines for collecting and interpreting innovation data[M].3rd ed.Paris:OECD,2005.
- [7]EUROPEAN COMMISSION.Green paper on innovation[M].Luxembourg,1995.
- [8]罗卓然,陆伟,蔡乐,程齐凯.学术文本词汇功能识别——在论文新颖性度量上的应用[J].情报学报,2022,41(7):720-732.
- [9]高自龙.创新性学术成果的发现与评鉴策略——基于编辑工作的思考[J].编辑之 友,2018(1):81-85.
- [10]索传军.知识转移视角下的学术论文老化与创新研究[J].图书情报工作,2014,58(5):5-12.
- [11]《科技查新教程》编写组.科技查新教程[M].北京:机械工业出版社,2001.
- [12] 张京辉,胡淑礼,王亚非,等.软科学成果查新研究[J].软科学,1993(4):28-33.
- [13] 陈永胜,孙昌玲.社会科学查新工作指标体系的结构模型与价值分析[J].情报资料工作,2002(6):6-8.
- [14] 徐华.浅谈学术论文的创新[J].价值工程,2013,32(36):259-260.
- [15]魏绪秋,申力旭.学术论文创新性研究述评[J].图书情报知识,2022,39(4):68-79.
- [16]Mishra S , Torvik V I . Quantifying Conceptual Novelty in the Biomedical Literature[J]. Dlib Mag, 2016, 22(9/10):1-21.
- [17] Heinze T, Shapira P, Rogers J, et al. Creativity capabilities and the promotion of highly innovative research in Europe and the United States[J]. Final report, Karlsruhe, 2007.
- [18] Sarah K,Keyvan V.The double-edged sword of recombination in breakthrough innovation[J].Strategic Management Journal,2015,36(10):1435-1457.
- [19]黄红,陈翀,张婧莹.科技文献内容语义识别研究综述[J].情报学报,2022,41(9):991-1002.
- [20]Nasar Z, Jaffry S W, Malik M K. Information extraction from scientific articles:a survey[J]. Scientometrics, 2018, 117(3):1931-1990.
- [21]李姗,单磊,崔雷.学术论文新颖性评价方式[J].中华医学图书情报杂志,2020,29(8):71-74.

- [22] 逯万辉,苏金燕,余倩.学术成果主题新颖性与学术引用的相关关系研究[J].情报资料工作,2018,(6):68-73.
- [23]张智雄,刘欢,于改红.构建基于科技文献知识的人工智能引擎[J].农业图书情报学报,2021,33(1):17-31.
- [24] 陈云伟.科技评价计量方法述评[J].农业图书情报学报,2020,32(8):4-11.
- [25] 卢超,侯海燕,Ding Ying,等.国外新兴研究话题发现研究综述[J].情报学报,2019,38(1):97-110.
- [26] Jarić I, Knežević-Jarić J, Lenhardt M. Relative age of references as a tool to identify emerging research fields with an application to the field of ecology and environmental sciences[J]. Scientometrics, 2014, 100: 519-529.
- [27] Llorente P, Gonzalez-Alcaide, et al. Bibliometric indicators to identify emerging research fields: publications on mass gatherings[J]. Scientometrics: An International Journal for All Quantitative Aspects of the Science of Science Policy, 2016, 109(2):1283-1298.
- [28] FUNK R,OWEN-SMITH J.A dynamic network measure of technological change[J].Management Science,2017,63(3):791-817.
- [29] LEE Y N, WALSH J P, WANG J. Creativity in scientific teams: unpacking novelty and impact[J]. Research Policy, 2015, 44(3):684-697.
- [30] WANG J, VEUGELERS R, STEPHAN P E.Bias against novelty in science: a cautionary tale for users of bibliometric indicators[J]. Research Policy, 2017, 46(8):1416-1436.
- [31] He Y, Luo J. Novelty, conventionality, and value of invention[C]//Design Computing and Cognition'16. Springer International Publishing, 2017: 23-38.
- [32] Mishra S, Torvik V I. Quantifying conceptual novelty in the biomedical literature[C]//D-Lib magazine: the magazine of the Digital Library Forum. NIH Public Access, 2016, 22(9-10).
- [33] CARAYOL N,LAHATTE A,LLOPIS O.Novelty in science presented at STI 2017[EB/OL].(2020-12-08].[2023-2-
- 11].https://digital.csic.es/bitstream/10261/162613/1/novelty.pdf.
- [34] TRAPIDO D.How novelty in knowledge earns recognition: the role of consistent identities[J].Research Policy, 2015, 44(8):1488-1500.
- [35] WU L, WANG D, EVANS J. Large teams develop and small teams disrupt science and technology [J]. Nature, 2019, 566 (7744):378-382.
- [36] 刘小慧,廖宇,朱曼曼.颠覆性指数用于科研评价初探[J].情报理论与实践,2021,44(12):34-40.
- [37] Frigotto M L, Riccaboni M. A few special cases: scientific creativity and network dynamics in the field of rare diseases[J]. Scientometrics, 2011, 89(1): 397-420.
- [38] 王军辉,谭宗颖.基于文献计量的科学创造力评价研究综述[J].图书情报工作,2017,61(3):131-139.
- [39] ZHANG Y, TSAI F S.Chinese novelty mining[EB/OL].(2017-01-08).[2022-11-3].https://dl.acm.org/doi/pdf/10.5555/1699648.1699703.
- [40] 杨建林,钱玲飞.基于关键词对逆文档频率的主题新颖度度量方法[J].情报理论与实践,2013,36(3):99-102.
- [41] 郭丽娜,李星琛,左文革,周群.颠覆性研究文献计量识别方法述评[J].数字图书馆论坛,2020,(3):17-24.

- [42] Harman D . Overview of the TREC 2002 Novelty Track[C]// Text REtrieval Conference. 2002.
- [43] 曾建勋.破除"SCI至上"需要弘扬"同行评议"[J].数字图书馆论坛,2020,(2):1-2.
- [44] 邢美凤,过仕明.文本内容新颖性探测研究综述[J].情报科学,2011,29(7):1098-1103.
- [45] 逯万辉,谭宗颖.学术成果主题新颖性测度方法研究——基于Doc2Vec和HMM算法[J].数据分析与知识发现,2018,2(3):22-29.
- [46] Tsai F S, Tang W, Chan K L. Evaluation of novelty metrics for sentence-level novelty mining[J]. Information Sciences, 2010, 180(12): 2359-2374.
- [47] 王平,侯景瑞,吴任力.基于递归张量神经网络的微信公众号文章的新颖度评估方法[J].情报学报,2019,38(2):159-169.
- [48] Luo Z, Lu W, He J, et al. Combination of research questions and methods: A new measurement of scientific novelty[J]. Journal of Informetrics, 2022, 16(2): 101282.
- [49] 褚婧丹.科技论文创新点原创性测度方法研究[D].北京: 中国科学院大学(中国科学院文献情报中心),2020.
- [50] 陈娜.基于知识组合视角的技术新颖性测度研究[D].大连: 大连理工大学,2021.
- [51] Sendhilkumar S, Mahalakshmi G S, Harish S, et al. Assessing novelty of research articles using fuzzy cognitive maps[M]//Intelligent Informatics. Springer, Berlin, Heidelberg, 2013: 73-79.
- [52] 秦岩,代君,廖莹驰.学术会议论文新颖性测度研究——以计算机学科人工智能领域为例 [J].情报科学,2021,39(1):104-110
- [53] Hautam äki V, K ärkk änen I, Fr änti P. Outlier detection using k-nearest neighbour graph[C]// Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004. IEEE, 2004.
- [54] 廖莹驰. 基于论文文本内容角度的学术会议新颖性及影响力评价[D].武汉:武汉大学.2019.
- [55] Zhang K,Zi J, Wu L G. New event detection based on indexing-tree and named entity[C]//Proceedings of the 30th annual international ACM SIGIR conference on Research and development in information retrieval.ACM,2007:215-222.
- [56] Amplayo R K, Hong S L, Song M. Network-based approach to detect novelty of scholarly literature[J]. Information sciences, 2018, 422: 542-557.
- [57] 丁芳媛. 基于新颖性和影响力的论文推荐方法研究[D].广州: 华南理工大学,2020.
- [58] 任海英,王德营,王菲菲.主题词组合新颖性与论文学术影响力的关系研究[J].图书情报工作,2017,61(9):87-93.
- [59] Matsumoto K, Shibayama S, Kang B, et al. Introducing a novelty indicator for scientific research: validating the knowledge-based combinatorial approach[J]. Scientometrics, 2021, 126(8): 6891-6915.
- [60] 许丹,徐爽,陈斯斯,等.基于自然语言词对法的文献主题新颖性探测研究[J].图书情报工作,2018,62(8):130-138.
- [61]杨京,王芳,白如江.一种基于研究主题对比的单篇学术论文创新力评价方法[J].图书情报工作,2018,62(17):75-83.
- [62] 张吉玉,张均胜.考虑时序的单篇科技文献新颖性评估方法[J].图书情报工作,2022,66(17):93-105.

- [63] 钱佳佳,罗卓然,陆伟.基于问题-方法组合的科技论文新颖性度量与创新类型识别[J].图书情报工作,2021,65(14):82-89.
- [64] 王艳艳,张均胜,乔晓东,等.基于问题一方法矩阵的文献新颖性评估方法[J].情报理论与实践,2021,44(2):90-95.
- [65] 曹树金,闫颂.基于语义角色信息的科技论文创新段落定位及功能句识别方法研究——以中文情报学领域论文为例[J].情报理论与实践,2022,45(11):1-9,20.
- [66] 张颖怡,章成志,Daqing He.学术论文中问题与方法识别及其关系抽取研究综述[J].图书情报工作,2022,66(12):125-138.
- [67] 罗卓然,王玉琦,钱佳佳,等.学术论文创新性评价研究综述[J].情报学报,2021,40(7):780-790.
- [68] 丁堃,赵昕航,林原,等.面向学术评价的论文画像研究[J].情报理论与实践,2022,45(9):94-101.
- [69] 中华人民共和国教育部.第五轮学科评估工作方案[EB/OL].(2020-11-02).[2022-11-16].http://www.moe.gov.cn/jyb_xwfb/moe_1946/fj_2020/202011/t20201102_497819.html.
- [70] 谢珍,马建霞,胡文静.学术代表作评价:方法述评与研究展望[J].情报理论与实践,2021,44(12):190-196.

通讯作者(Corresponding author): 李涵昱(Li Hanyu), ORCID: 0000-0003-1426-3242, E-mail: lihy@mail.las.ac.cn。

基金项目: 本文系"国家社会科学基金重大项目"基金项目(项目编号: 21&ZD329)和"国家重点研发计划"基金项目(项目编号: 2022YFF0711900)的研究成果之一。

The work is supported by Major program of the National Social Science Foundation of China (Grant No. 21&ZD329), the National Key Research and Development Program of China (Grant No. 2022YFF0711900).

作者贡献声明:

吴欣雨: 收集整理文献, 撰写论文;

李涵昱:设计论文框架,论文修订;

张智雄: 提出研究分析思路, 论文修订;

吴振新:论文修订。

利益冲突声明:

所有作者声明不存在利益冲突关系。